

IoT센서로 수집된 균질 시간 데이터를 이용한 기계학습 기반의 품질관리 및 데이터 보정

김혜진¹, 이현수², 최병진³, 김용혁^{4*}

¹광운대학교 컴퓨터과학과 석사과정, ²(주)주빅스 기술연구소 연구원,
³(주)주빅스 기술연구소 이사, ⁴광운대학교 컴퓨터과학과 교수

Machine Learning-based Quality Control and Error Correction Using Homogeneous Temporal Data Collected by IoT Sensors

Hye-Jin Kim¹, Hyeon Soo Lee², Byung Jin Choi³, Yong-Hyuk Kim^{4*}

¹Master Student, Dept. Computer Science, Kwangwoon University

²Researcher, R&D Center, JUBIX Co., Ltd.

³Director, R&D Center, JUBIX Co., Ltd.

⁴Professor, Dept. Computer Science, Kwangwoon University

요 약 본 논문은 온도 등 7 가지의 IoT 센서에서 수집된 기상데이터의 각 기상요소에 대하여 품질관리(Quality Control; QC)를 하였다. 또한, 우리는 측정된 값에 오류가 있는 데이터를 기계학습으로 의미있게 추정하는 방법을 제안한다. 수집된 기상데이터를 기본 QC 결과를 바탕으로 오류 데이터를 선형 보간하여 기계학습 QC를 진행하였으며, 기계학습 기법으로는 대표적인 서포트벡터회귀, 의사결정테이블, 다층퍼셉트론을 사용했다. 기본 QC의 적용 유무에 따라 비교해 보았을 때, 우리는 기본 QC를 거쳐 보간한 기계학습 모델들의 평균절대오차(MAE)가 21% 낮은 것을 확인할 수 있었다. 또한, 기계학습 기법에 따라 비교하여 서포트벡터회귀 모델을 적용하였을 때가, 모든 기상 요소에 대하여 MAE가 평균적으로 다층신경망은 24%, 의사결정테이블은 58% 낮은 것을 알 수 있었다.

주제어 : 융합, 기계학습, 품질관리, 데이터보정, 서포트벡터회귀, 다층퍼셉트론

Abstract In this paper, quality control (QC) is applied to each meteorological element of weather data collected from seven IoT sensors such as temperature. In addition, we propose a method for estimating the data regarded as error by means of machine learning. The collected meteorological data was linearly interpolated based on the basic QC results, and then machine learning-based QC was performed. Support vector regression, decision table, and multilayer perceptron were used as machine learning techniques. We confirmed that the mean absolute error (MAE) of the machine learning models through the basic QC is 21% lower than that of models without basic QC. In addition, when the support vector regression model was compared with other machine learning methods, it was found that the MAE is 24% lower than that of the multilayer neural network and 58% lower than that of the decision table on average.

Key Words : Convergence, Machine Learning, Quality Control, Data Correction, Weather Data

*This research was supported by a grant (19CTAP-C130211-03) from Technology Advancement Research Program (TARP) Program funded by Ministry of Land, Infrastructure and Transport of Korean government

*Corresponding Author : Yong-Hyuk Kim(yhdfly@kw.ac.kr)

Received January 28, 2019

Revised March 14, 2019

Accepted April 20, 2019

Published April 28, 2019

1. 서론

IoT 센서를 통해 수집할 수 있는 기상 데이터의 사용은 기상예측에만 국한되는 것이 아니라, 교통, 건설, 마케팅 등의 다양한 분야에 활용될 수 있다. 그러나, IoT 센서를 통해 수집된 기상 데이터는 실시간 연속모니터링 특성상 장비 및 네트워크의 고장, 통신장애로 인한 대체자료 생성 적용 등의 이유로 잘못된 데이터들이 기록되어 원시 데이터 분석에 좋지 않은 영향을 줄 수 있다. 이러한 문제를 해결하기 위해서는 품질관리(quality control; QC)를 통해 무의미한 데이터들을 탐지하고 더 나아가 잘못된 관측된 데이터를 보정하는 과정이 필요하다. 우리는 본 논문에서, 7 가지의 IoT 센서를 이용하여 수집된 기상 데이터를 물리 한계 등을 검사하는 기본 QC하며, 기상 요소의 기본 QC의 결과를 바탕으로 데이터 보간을 진행한다. 또한, 우리는 기계학습 기법을 사용하여 기상데이터를 QC하고 값을 추정하는 방법을 제안한다. 본 논문의 구성은 다음과 같다.

먼저, 2 절에서는 기계학습을 이용한 데이터 보정에 대한 선행 연구들에 대하여 정리하였다. 3 절에서는 IoT 센서를 이용하여 수집한 기상 데이터들에 대하여 설명하였으며, 4 절에서는 본 논문에서 사용한 3 가지의 기본 QC에 대하여 설명하였다. 그리고 5 절에서는 기계학습을 이용한 QC에 대하여 해당 QC의 방법론과 데이터 보정 방법 등에 대하여 기술하였다. 6 절에서는 기계학습을 이용한 QC를 진행하고, 실험 결과에 대하여 정리하였다. 마지막으로, 7 절에서는 본 연구의 결론과 향후 필요한 연구들을 언급하며 논문을 마무리 한다.

2. 관련연구

기상데이터의 다양한 활용과 함께 그에 따라 관련 선행 연구가 활발히 되어왔으며, 기계학습을 접근 방법으로 선택한 연구가 많다. Kim 등[1]은 안드로이드 기반 스마트폰에 내장된 미세 전자 기계식 압력 센서로 기압데이터를 기상데이터로 사용할 수 있도록 보정 방법을 제안하였다. 제안된 보정 방법은 선형회귀 분석을 이용하였으며, 공간적인 위치와 온도 및 습도에 대하여 품질관리 할 수 있다. Lee 등[2]은 서포트벡터회귀를 이용하여 비정상적으로 관측된 값을 결정하고 값을 예측하였다. 해당 방법을 사용하여 실시간 데이터셋을 수집하여 실험

한 결과, 서포트벡터 회귀를 이용한 계획 방법은 루트평균제곱오류를 평균 45.4% 줄였다. Ha 등[3]은 자동 기상 관측 장비인 AWS(automatic weather station)의 비용, 설치 공간 등에 대한 단점을 보완하는 AWS보다 훨씬 작은 Mini-AWS를 개발하였다. Mini-AWS는 설치비용과 유지관리비용, 설치공간에 대하여 이점이 있으나, 설치 영역에 따라 외부 환경의 영향을 받을 수 있으므로 보정이 필요하다. 그들은 보정을 위해 기계학습을 이용하여 기압 데이터를 보정하였다. Kim 등[4]은 스마트폰에서 얻은 기압 데이터를 시간 영역 분류를 통해 클러스터링 및 회귀분석을 수행하였다. 또한, 그들은 다층퍼셉트론 및 서포트벡터회귀와 같은 기계학습 방법들의 결과를 분석한다. Lee 등[5]은 AWS에서 수집된 데이터중 비정상적으로 수집된 데이터를 복구하는 연구를 진행했다. 기계학습 기법을 기반으로 3 가지의 추정 모델을 제시하고, 기존의 추정방법과 보간법과 비교하였다. 5년 동안의 한국의 692 개의 지역에 대하여 기존의 방법들보다 목표값을 더 잘 추정하는 결과를 확인하였다. Kim과 Kim[6]은 해양 뜰개를 이용하여 관측한 데이터의 오류를 보정하기 위해서 순환신경망 모델을 제안하였다. 실험을 통해 13.9%의 데이터를 보정하고 이동 예측 모델의 성능을 1.4% 향상되는 것을 보였다.

3. 기상데이터

우리는 본 연구를 위해 2018년 4월 2일부터 8일까지 7일 동안 그림 1과 같은 경기도 고양시 덕양구(위도: 37.708, 경도: 126.895)에 위치한 7 가지 IoT 센서들로부터 기상데이터를 수집하였다. 사용된 IoT 센서들의 종류와 관측한 기상요소는 표 1과 같으며, 해당 센서들의 설치시기는 2016년 12월 9일로 모두 동일하다. 우리는 표 1에 나와 있는 기상 요소들 중 풍향과 풍속은 u 와 v 로 변

Table 1. Information on sensors collecting weather data

Type of Sensor	Weather data
MHT-100T	temperature (°C)
FST200-202	wind direction (degree)
FST200-201	wind speed (m/s)
MHT-100T	humidity (%)
SP-110	solar radiation (W/m ²)
SU-100	UV-rays (W/m ²)
ES-642	air-PM2.5 (μm ³)




Fig. 1. Location of the place where IoT sensors are installed (Latitude: 37.708, Longitude: 126.895)

환하였으며, 총 7 가지의 기상요소에 대하여 1 분 단위로 품질관리 하고 기계학습을 이용하여 데이터 보정을 수행한다.

4. 기본 품질관리

본 논문에서 3 가지의 기본 QC를 진행하였으며, 각 품질관리에 대한 설명은 다음과 같으며, 표 2는 각 기본 QC의 세부정보를 나타낸 것이다. 이와 같은 기본 QC를 적용한 후의 결과는 표 3과 같다.

물리 한계 검사(physical limit test): 물리한계 검사는 각 기상요소 별로 측정된 수치가 상한 값이나 하한 값을 벗어나는 경우에 오류로 판정한다.

시간 변동성 검사(time consistency test): 시간 변동성 검사는 IoT 센서에서 측정된 값이 1분전에 측정된 값과 차이가 임계값보다 큰 경우에 오류로 판정한다.

지속성 검사(persistence test): 지속성 검사에서는 60 분 이상동안 수치의 변동한 크기가 기준이 되는 크기에 미치지 못 할 경우 오류로 판정한다.

Table 2. Details of basic quality control

	Physical limit		Time consistency	Persistence
	Min	Max	Max variation	Min variation
Tem	-40	60	0.1	0.1
Humidity	0	100	1	1
UV-rays	-	-	-	-
PM2.5	0.1	359.9	-	-

SR	0	0	-	-
u	0	360	-	-
v	0	75	1	0.5

Table 3. Error rate of basic quality control (%)

	Physical limit		Time consistency		Persistence	
	#err/#total	Rate _{err}	#err/#total	Rate _{err}	#err/#total	Rate _{err}
Tem	0/10060	0.0	251/10060	2.5	0/10060	0.0
Humidity	0/10060	0.0	798/10060	7.9	0/10060	0.0
UV-rays	0/10060	0.0	0/10060	0.0	0/10060	0.0
PM2.5	34/10060	0.3	0/10060	0.0	0/10060	0.0
SR	0/10060	0.0	0/10060	0.0	0/10060	0.0
u	0/10060	0.0	1571/10060	15.6	0/10060	0.0
v	0/10060	0.0	1571/10060	15.6	0/10060	0.0

*Tem is temperature and SR is solar radiation.

5. 기계학습을 이용한 품질관리

5.1 방법론

본 논문에서 제안한 기계학습을 이용한 QC 및 데이터 보정을 위한 순서도는 그림 2와 같다. 기본 QC를 거치고

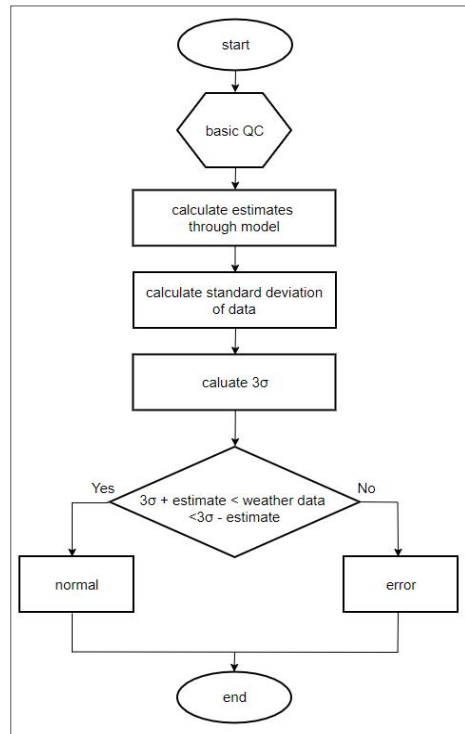


Fig. 2. Flowchart of quality control using machine learning

나서 기계학습을 이용하여 모델을 생성하게 되고, 10 분 간의 과거 데이터를 이용하여 모델을 통해 각 기상요소에 독립적으로 현재 추정치를 계산한다. 그리고 과거 10 분간의 데이터의 표준편차(σ)를 계산하여 기계학습 QC를 통과할 수 있는 범위를 설정한다. 만약 기계학습을 이용하여 만들어진 추정치가 정해놓은 범위 내에 존재한다면 정상으로, 범위에서 벗어난다면 오류로 QC한다.

5.2 입력 데이터 보간

기본 QC를 통과하지 못한 값들은 보간 절차를 거친다. 기본 QC를 통해 오류로 판정된 데이터가 양 끝에 연속적으로 위치하지 않는다면, 데이터의 개수에 상관없이 해당 선형적인 방법으로 데이터를 보간한다. 반면에, 보

정이 필요한 데이터들이 양 끝에 위치하며 오류값이 2 개 이상의 경우 행을 제외하였다. 이러한 과정을 거친 데이터들은 보간된 데이터가 오류값인 경우에 행을 제외하는 절차를 거쳐 보간을 끝낸다.

5.3 품질관리

기계학습을 이용한 QC는 3 가지로 나누어 실험을 진행하였다. 첫 번째는 원시데이터로 기계학습하는 것이며, 두 번째는 기본 QC를 적용하였으나 보간하지 않고 기계학습하는 것이며, 세 번째는 기본 QC 결과를 보간하여 기계학습하는 것이다. 본 논문에서 사용한 기계학습 알고리즘의 종류는 3 가지이며, 소프트웨어회귀[7], 의사결정테이블[8], 다층퍼셉트론[9]이 이에 해당된다.

Table 4. Machine learning-based QC and error correction results on raw data

	Support vector regression				Multilayer perceptron				Decision table			
	MAE	3 σ error		Time(s)	MAE	3 σ error		Time(s)	MAE	3 σ error		Time(s)
		#err/#total	Rate_err(%)			#err/#total	Rate_err(%)			#err/#total	Rate_err(%)	
Tem	0.035	292/10050	3	1464	0.048	1710/10050	17	53	0.521	7680/10050	76	4
humidity	0.331	148/10050	1	2378	0.512	1585/10050	16	53	1.532	6752/10050	67	5
UV-rays	0.508	4508/10050	44	2202	0.926	3688/10050	37	49	1.759	7033/10050	70	2
PM2.5	2.740	390/10050	4	888	4.282	772/10050	8	54	4.669	3466/10050	34	8
SR	0.002	138/10050	1	1126	0.003	88/10050	1	50	0.002	136/10050	1	2
u	0.343	432/10050	4	717	0.521	1006/10050	10	52	0.396	794/10050	8	5
v	0.425	565/10050	6	704	0.497	1420/10050	14	53	0.499	1158/10050	12	4
Average	0.626	925/10050	9	1354	0.970	1467/10050	15	52	1.340	3860/10050	38	4

Table 5. Machine learning-based QC and error correction results on non-interpolated data after basic QCs

	Support vector regression				Multilayer perceptron				Decision table			
	MAE	3 σ error		Time(s)	MAE	3 σ error		Time(s)	MAE	3 σ error		Time(s)
		#err/#total	Rate_err(%)			#err/#total	Rate_err(%)			#err/#total	Rate_err(%)	
Tem	31.240	8742/10050	87	1420	42.507	8402/10050	84	48	42.631	8910/10050	89	2
humidity	98.569	2956/10050	29	4154	163.888	7264/10050	72	49	119.810	7239/10050	72	2
UV-rays	0.508	4508/10050	44	2202	0.926	3688/10050	37	49	1.759	7033/10050	70	2
PM2.5	9.283	843/10050	8	829	25.650	7313/10050	73	49	17.620	6870/10050	68	2
SR	0.002	138/10050	1	1126	0.003	88/10050	1	50	0.002	136/10050	1	2
u	160.864	928/10050	9	4091	291.154	5539/10050	55	49	205.336	5523/10050	55	2
v	160.932	964/10050	10	4336	289.946	5524/10050	55	48	205.413	5524/10050	55	2
Average	65.914	2726/10050	27	2594	116.296	5403/10050	54	49	84.653	5891/10050	59	2

Table 6. Machine learning-based QC and error correction results on interpolated data after basic QCs

	Support vector regression				Multilayer perceptron				Decision table			
	MAE	3 σ error		Time(s)	MAE	3 σ error		Time(s)	MAE	3 σ error		Time(s)
		#err/#total	Rate_err(%)			#err/#total	Rate_err(%)			#err/#total	Rate_err(%)	
Tem	0.032	287/9665	2	1402	0.0457	493/9665	5	46	0.4975	7716/9665	80	2
humidity	0.3034	129/6429	2	798	0.3985	281/6429	4	31	1.8134	4315/6429	67	1
UV-rays	0.5075	4508/10050	44	2202	0.9263	3688/10050	37	49	1.7586	7033/10050	70	2
PM2.5	2.0483	388/10013	3	928	2.437	405/10013	4	50	3.4803	3398/10013	34	2
SR	0.0021	138/10050	1	1126	0.0032	88/10050	1	50	0.0024	136/10050	1	2
u	0.2347	332/7254	4	165	0.3345	419/7254	6	34	0.2601	501/7254	7	2
v	0.2687	436/7254	6	219	0.3436	478/7254	7	16	0.3043	613/7254	8	2
Average	0.485	888/8674	9	977	0.641	836/8674	9	39	1.160	3387/8674	38	2

서포트벡터회귀는 서포트벡터머신(support vector machine; SVM)[10]을 이용하여 회귀분석[11]하는 알고리즘이다. 우리가 사용한 다른 하나의 기계학습 알고리즘으로는 의사결정테이블(decision table)이 있다. 해당 알고리즘은 여러 개의 분류자를 만들고 사용하기 위한 알고리즘이다. 마지막으로 다층퍼셉트론은 다층신경망 구조로, 인스턴스를 분류하기 위해 오류역전파(backpropagation)[12]를 이용하는 알고리즘이다. 우리는 과거에 측정된 10 분간의 데이터를 기계학습하여 현재의 값을 추정하고 10차 교차검증[13]으로 기계학습을 통해 생성된 모델을 검증한다.

6. 실험결과

우리는 3.60 GHz의 AMD Ryzen 5 1600X CPU(six-core)와 16 GB의 메모리를 사용하여 실험환경을 구성하였으며, 기계학습 라이브러리인 Weka 3.8[14, 15]을 이용하여 모델들을 적용하였다. 원시데이터를 기계학습 하였을 때의 3σ 오류율, 평균절대오차 및 수행시간은 표 4와 같으며, 3σ 오류율은 서포트벡터회귀가 9%, 다층퍼셉트론이 15%, 의사결정테이블이 38%였다. 기본 QC를 적용하였으나 보간하지 않은 데이터의 결과는 표

5와 같으며, 3σ 오류율은 기법들에 따라 각각 27%, 54%, 59%로 가장 높은 오류율을 보였다. 마지막으로, 기본 QC 결과를 보간하고 기계학습 QC를 거친 데이터의 기계학습 결과는 표 6과 같으며, 3σ 오류율은 기법들에 따라 각각 9%, 9%, 38%로 가장 낮은 오류율을 보였다. 또한 그림 3은 습도에 대한 원시데이터를 그래프로 나타낸 것이며, 그림 4는 습도에 대하여 기본 QC에서 오류로 판단되었던 데이터를 서포트벡터회귀를 적용하여 보정한 그래프이다.

원시데이터와 기본 QC후 보간하지 않은 데이터의 평균 MAE를 비교해 보았을 때, 제안된 방법은 각각 22%, 99%씩 감소된 결과였다. 한편, 기계학습 기법들을 비교해 보았을 때 모든 실험에서 서포트벡터회귀를 적용한 실험들의 결과가 가장 좋았다. 서포트벡터회귀를 적용하였을 경우에 평균적으로 MAE는 다층퍼셉트론보다 24%, 의사결정테이블보다 58% 감소하였다. 또한, 서포트벡터회귀를 사용한 실험들을 비교해 보았을 때 기본 QC후 보간한 경우가 기본 QC후 보간하지 않은 경우보다 MAE가 99%, 원시 데이터를 사용한 경우가 22%로 각각 감소하였음을 확인하였다. 그러나, 서포트벡터회귀가 모든 경우에 가장 좋은 성능을 보였지만 시간 또한 가장 오래 소요되었다.




Fig. 3. Raw data of humidity (data regarded ed as error in the basic QC are marked on the X-axis)




Fig. 4. Graph of humidity data corrected using support vector regression

7. 결론 및 향후연구

본 논문에서는 기존에 사용되는 선형보간법과 달리, 기계학습 기법을 사용하여 기상데이터를 QC하는 방법을 제안하였다. 실험을 통해 우리가 제안한 기본 QC후 기계학습 QC를 한 경우의 모든 기계학습 기법에 대하여 MAE가 가장 낮은 것을 확인할 수 있었다.

본 논문에서는 각 기상요소에 독립적으로 QC를 진행하였으나, 이러한 연구 결과를 바탕으로 과거 데이터와 현재 측정된 다른 요소를 이용하여 현재 값을 추정하거나[5], 다른 지점에 위치하는 IoT 센서들에서 얻은 관측값으로 현재 지점의 관측값을 추정하여 QC를 하는 연구[2]가 향후 가능할 것이다.

REFERENCES

- [1] N.-Y. Kim, Y.-H. Kim, Y. Yoon, H.-H. Im, R. K. Y. Choi, and Y. H. Lee. (2015). Correcting air-pressure data collected by MEMS sensors in smartphones. *Journal of Sensors, Article ID 245498*.
- [2] M.-K. Lee, S.-H. Moon, Y. Yoon, Y.-H. Kim, and B.-R. Moon. (2018). Detecting anomalies in meteorological data using support vector regression. *Advances in Meteorology, Article ID 5439256*.
- [3] J.-H. Ha, Y.-H. Kim, H.-H. Im, N.-Y. Kim, S. Sim, and Y. Yoon. (2018). Error correction of meteorological data obtained with Mini-AWSs based on machine learning. *Advances in Meteorology, Article ID 7210137*.
- [4] Y.-H. Kim, J.-H. Ha, Y. Yoon, N.-Y. Kim, H.-H. Im, S. Sim, and R. K. Y. Choi. (2016). Improved correction of atmospheric pressure data obtained by smartphones through machine learning. *Computational Intelligence and Neuroscience, Article ID 9467878*.
- [5] M.-K. Lee, S.-H. Moon, Y.-H. Kim, and B.-R. Moon. (2014. October). Correcting abnormalities in meteorological data by machine learning. *IEEE International Conference on Systems, Man, and Cybernetics*. (pp.888-893). San Diego : IEEE
- [6] G.-D. Kim & Y.-H. Kim. (2018). Correction of drifter data using recurrent neural networks. *Journal of the Korea Convergence Society, 9(3)*, 15-21.
- [7] A. J. Smola & B. Schölkopf. (2004). A tutorial on support vector regression. *Statistics and Computing, 14(3)*, 199-222.
- [8] U. W. Pooch. (1974). Translation of decision tables. *ACM Computing Surveys, 6(2)*, 125-151.
- [9] F. Rosenblatt (1961). *Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms*, Washington DC : Spartan Books.
- [10] J. A. Suykens & J. Vandewalle. (1999). Least squares support vector machine classifiers. *Neural Processing Letters, 9(3)*, 293-300.
- [11] N. R. Draper & H. Smith. (1998). *Applied Regression Analysis, Thirds Edition*.Wiley.
- [12] M. Riedmiller & H. Braun. (1993). A direct adaptive method for faster backpropagation learning: the RPROP algorithm. *IEEE International Conference on Neural Networks*. (pp.586-591).
- [13] R. Kohavi. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. *International Joint Conference on Artificial Intelligence Organization, 14(2)*, 1137-1145. San Francisco : Morgan Kaufmann.
- [14] E. Frank, M. A. Hall, and I. H. Witten. (2016). *Data Mining: Practical Machine Learning Tools and Techniques, Fourth Edition*. Morgan Kaufmann.
- [15] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, and I. H. Witten. (2009). The WEKA data mining software: an update. *Newsletter of SIGKDD Explorations, 11(1)*, 10-18.

김혜진(Kim, Hye-Jin)

[학생회원]



- 2018년 2월 : 광운대학교 컴퓨터소프트웨어학과(공학사)
- 2018년 3월 ~ 현재 : 광운대학교 대학원 컴퓨터과학과 석사과정
- 관심분야 : 인공지능, 유전알고리즘, 기계학습

· E-Mail : ovoa22@gmail.com

이현수(Lee, Hyeon Soo)

[정회원]



- 2017년 2월 : 순천향대학교 컴퓨터공학과(공학사)
- 2017년 7월 ~ 현재 : ㈜주빅스 연구원
- 관심분야 : 기계학습, IoT 분야
- E-Mail : hslee@jubix.co.kr

최 병 진(Choi, Byung Jin) [정회원]



- 1987년 2월 : 서울시립대학교 환경 공학과(공학사)
- 2014년 12월 ~ 현재 : ㈜주빅스 기술연구소 이사
- 관심분야 : 시계열 예측분야, 대기 확산모델링, 이상탐지

· E-Mail : cbjin@jubix.co.kr

김 용 혁(Kim, Yong-Hyuk) [정회원]



- 1999년 2월 : 서울대학교 전산학과(이학사)
- 2001년 2월 : 서울대학교 전기컴퓨터공학부(공학석사)
- 2005년 2월 : 서울대학교 전기컴퓨터공학부(공학박사)

· 2005년 3월 ~ 2007년 2월 : 서울대학교 반도체공동연구소 연구원

· 2007년 3월 ~ 2017년 2월 : 광운대학교 컴퓨터소프트웨어학과 조교수/부교수

· 2017년 3월 ~ 현재 : 광운대학교 소프트웨어학부 교수

· 관심분야 : 최적화, 진화연산, 지식공학

· E-Mail : yhdffy@kw.ac.kr